

Interfaces Computador-Cérebro: Extracção e Processamento de Características de Electroencefalogramas

Inês Oliveira, Luís Carriço, Nuno Guimarães,
Teresa Chambel, Carlos Teixeira

DI-FCUL

TR-08-05

Fevereiro 2008

Departamento de Informática
Faculdade de Ciências da Universidade de Lisboa
Campo Grande, 1749-016 Lisboa
Portugal

Technical reports are available at <http://www.di.fc.ul.pt/tech-reports>. The files are stored in PDF, with the report number as filename. Alternatively, reports are available by post from the above address.

RESUMO

As interfaces computador-cérebro são uma abordagem recente para comunicar e controlar dispositivos através de actividades mentais. Este tipo de tecnologia poderá, por exemplo, ser usado no controlo de membros artificiais ou outros dispositivos ou no tratamento de algumas patologias.

Para reconhecer as actividades mentais, os mecanismos de comunicação computador-cérebro necessitam analisar e processar registos da actividade cerebral, nos quais se incluem os electroencefalogramas. Nestes registos procura-se identificar os padrões da actividade cerebral que caracterizam univocamente os comandos mentais desejados

Devido à facilidade da sua aplicação e baixo custo, os electroencefalogramas são frequentemente usados nas interfaces computador-cérebro, embora a sua análise e processamento sejam complexos. Os padrões obtidos nos registos variam com o operador e são afectados por vários tipos de perturbações, como por exemplo os movimentos oculares.

Este relatório sistematiza assim algumas das técnicas de análise e processamento de electroencefalogramas utilizadas nas interfaces computador-cérebro. Entre estas, encontram-se os procedimentos mais comuns para o tratamento de interferências no sinal, a selecção e extracção de atributos e a classificação destes atributos nas várias actividades mentais.

O levantamento registado neste documento inicia um objectivo de investigação mais vasto, no qual se pretende utilizar técnicas de análise e processamento de electroencefalogramas na avaliação da usabilidade de interfaces.

1 Introdução

Os mecanismos de comunicação computador-cérebro (também conhecidos como *Brain-Computer Interfaces*) são uma concretização de uma aspiração antiga da humanidade – “controlar o mundo através da mente” [1]. Este tipo de interfaces tem como principal objectivo ser uma forma alternativa de comunicação e controlo; ou seja, permitir ao utilizador operar executando tarefas mentais, sem depender do resultado normal dos nervos e músculos periféricos [2]. Uma forma de comunicação tão inovadora com esta poderá ser aplicada em áreas tão diversas como o controlo imersivo de jogos [3], a estimulação eléctrica funcional¹ [4] ou ainda o tratamento de determinadas patologias, como é o caso do Síndrome de Déficit de Atenção [5].

Para decodificar os comandos mentais, as interfaces computador-cérebro requerem a análise e processamento de sinais biomédicos cerebrais. Existem actualmente vários tipos de técnicas que procuram medir a actividade cerebral, como por exemplo: electroencefalogramas, ressonâncias magnéticas ou tomografias por emissão de positrões. Dentro deste conjunto, os electroencefalogramas são a forma menos dispendiosa e intrusiva de medir a actividade cerebral, sendo por isso frequentemente utilizados nas interfaces computador-cérebro [6] [7]. A análise e processamento de electroencefalogramas não são contudo triviais: os padrões cerebrais variam com o utilizador e são afectados por ruído, movimentos oculares e musculares [7].

Posto isto, este estudo tem assim como objectivo principal apresentar e sistematizar algumas das técnicas de análise e processamento de electroencefalogramas mais utilizadas nas interfaces computador-cérebro. Estes procedimentos procuram em geral tratar os seguintes problemas:

- **Tratamento das interferências** — perturbações não resultantes da actividade cerebral que afectam o sinal;
- **Extracção das propriedades** — selecção e obtenção dos atributos que melhor caracterizam os padrões resultantes das várias actividades mentais, para utilizar no seu posterior reconhecimento;
- **Classificação** — classificação dos conjuntos de atributos acima extraídos nas várias actividades mentais com base no reconhecimento dos seus padrões característicos.

¹ A aplicação de corrente eléctrica aos músculos para melhorar ou produzir função; membro artificial controlado mentalmente.

Este documento foi elaborado no âmbito da cadeira Tópicos Avançados em Sistemas de Informação II, leccionada na Faculdade de Ciências no âmbito do plano de estudos avançado de doutoramento. Este levantamento trata-se assim de uma fase preliminar de um objectivo de investigação mais vasto, no qual se pretende utilizar técnicas de análise e processamento de electroencefalogramas para a avaliação da usabilidade de interfaces. A restante organização do documento é a seguinte:

- Na secção 2 é apresentada a arquitectura típica de um sistema de comunicação computador-cérebro, como forma de enquadrar os procedimentos apresentados;
- Na secção 3 são descritas as características e fenómenos dos electroencefalogramas mais relevantes no âmbito deste estudo;
- Nas secções 4, 5 e 6 detalham-se respectivamente as técnicas mais comuns de tratamento de interferências, de extracção de características e de classificação utilizadas em interfaces computador-cérebro baseadas em electroencefalogramas;
- Por fim, a secção 7 e 8 apresentam a discussão e as conclusões.

2 Interfaces Computador-Cérebro

As interfaces computador-cérebro são sistemas de comunicação em que os dispositivos são controlados através de actividades mentais, não passando através das saídas normais do cérebro – os músculos e nervos periféricos [6]. As actividades mentais podem ser, entre outras, respostas originadas por estímulos externos, movimento de membros imaginários, operações espaciais (e.g. mover um cursor), geométricas (e.g. a intersecção de duas figuras geométricas), aritméticas e verbais [6]. Os dispositivos controlados podem ser tão variados como computadores, sintetizadores de fala, próteses neuronais, entre outros [7] [8].

A Figura 1 mostra um modelo funcional típico de um destes sistemas. O **utilizador** controla um dispositivo através de uma interface computador-cérebro. Os **eléctrodos** convertem o estado cerebral do utilizador em sinais eléctricos que são posteriormente digitalizados, amplificados e filtrados através de **amplificadores**. Os sinais resultantes são transformados em vectores de propriedades através do **módulo de extracção de características**. Estes vectores são então traduzidos em sinais de controlo independentes do dispositivo através do **módulo de tradução** (classificação se for no caso discreto). A **interface de controlo** adequa estes sinais ao dispositivo a controlar e o **controlador do dispositivo** converte-os para os sinais físicos de controlo propriamente ditos.

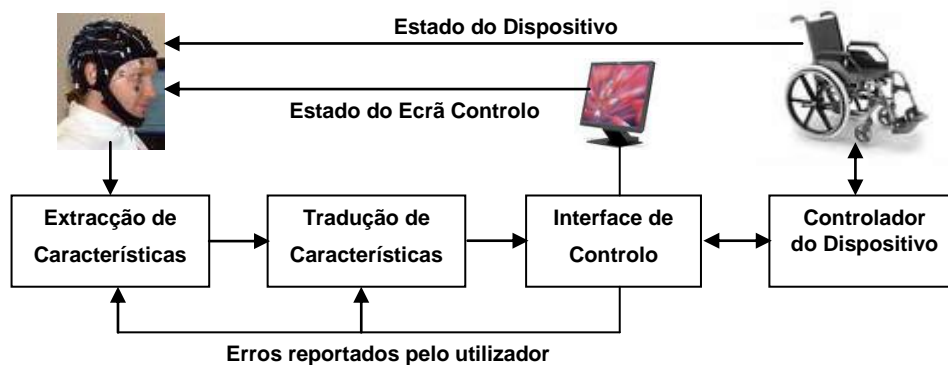


Figura 1- Modelo funcional típico de um sistema de comunicação computador-cérebro [8].

Adicionalmente, pode ainda existir um **ecrã de controlo** que permite ao utilizador visualizar as acções resultantes das actividades mentais processadas e assim monitorizar o estado do dispositivo para determinar o resultado do seu esforço [8]. Alguns sistemas de comunicação computador-cérebro englobam ainda um **estimulador sensorial externo** para causar determinados fenómenos cerebrais, como é o caso por exemplo dos potenciais relacionados com eventos (ver detalhes sobre os potenciais relacionados com eventos na ver secção 3.2.2).

As interfaces computador-cérebro podem ser classificadas em síncronas ou assíncronas consoante respondam síncrona ou assincronamente às actividades mentais do utilizador [7] [8]. Estas podem ainda ser categorizadas nos seguintes tipos [7] [8]:

- **Interfaces baseadas em respostas relacionadas com estímulos externos** (ou *Event Related Potentials*), se reagem às respostas dos utilizadores geradas quando estes são expostos a determinados estímulos externos, nomeadamente, imagens, sons, entre outros;
- **Interfaces condicionadas pelo operador**, quando o operador é treinado para fornecer a resposta mental desejada para realizar uma dada actividade;
- **Interfaces baseadas em análise espacial**, se reagem simplesmente a determinados padrões espaciais, sem recurso a qualquer tipo de estímulo ou treino.

As interfaces baseadas em respostas relacionadas com estímulos externos [7] [8] baseiam-se na ideia de que a mente é uma unidade de processamento de informação, cujos resultados dependem da utilização de estímulos para activar determinados processos cognitivos. Estes estímulos, que podem ser visuais, auditivos, etc., provocam sinais transitórios nos electroencefalogramas – os potenciais relacionados com eventos. Estes sinais podem ser

reconhecidos e associados a determinadas acções, permitindo ao utilizador controlar a interface focando a sua atenção no estímulo correspondente à acção pretendida.

As interfaces por condicionamento dos operadores [7] requerem que estes aprendam previamente a “modelar” a sua actividade cerebral, para fornecer respostas mentais que permitam o controlo da interface. Para reconhecer o comando pretendido, o computador utiliza algoritmos de aprendizagem.

As aproximações baseadas em análise espacial [8] procuram detectar padrões na distribuição espacial das propriedades dos vários eléctrodos, sem recurso a treino prévio. Este tipo de interfaces pode, por exemplo, analisar as assimetrias causadas pelas actividades mentais nos hemisférios cerebrais.

3 Electroencefalogramas

Os electroencefalogramas são uma técnica fisiológica que mede a função do cérebro através da monitorização da actividade eléctrica cerebral. Estes registos são obtidos através de eléctrodos – pequenos sensores arredondados, colocados na cabeça em intervalos regulares [9]. Embora existam outras técnicas de medição da função cerebral mais eficazes [6], os electroencefalogramas são frequentemente usados em interfaces computador-cérebro devido às seguintes vantagens [7]:

- são facilmente capturados;
- são completamente não invasivos, pelo que podem ser aplicados repetidamente sem riscos ou limitações;
- são pouco dispendiosos;
- existe clara evidência que mudanças observáveis nos sinais resultam do desempenho de determinadas actividades mentais.

Os electroencefalogramas permitem medir a frequência e intensidade das ondas eléctricas cerebrais e, como são não invasivos, podem ser capturados durante períodos relativamente longos. O sinal resultante mostra picos característicos relacionados com a existência de actividade eléctrica, mas revela informação muito geral sobre a sua localização espacial, uma vez que esta se encontra apenas associada à localização dos eléctrodos. Este sinal resulta da soma da actividade de um elevado número de neurónios que comunicam uns com os outros através de sinais electroquímicos [6].

As restantes técnicas de medição da actividade cerebral são técnicas de imagem, dividindo-se em estáticas e metabólicas [6]. Estas técnicas são invasivas, estáticas ou então

demasiadamente dispendiosas para serem usadas em interfaces computador-cérebro. A secção 3.1 descreve de forma resumida estas técnicas.

Os registos electroencefalográficos podem mostrar diferentes tipos de padrões característicos, dependendo do nível de consciência e do tipo de estímulo, que os mecanismos de comunicação computador-cérebro procuram reconhecer para os associar a determinadas actividades mentais. A secção 3.2 descreve este tipo de padrões, seguindo-se uma última secção que descreve as interferências que podem ocorrer no sinal e prejudicar o reconhecimento das actividades mentais.

3.1 Outras Técnicas de Medição da Actividade Cerebral

As restantes técnicas de medição da actividade cerebral, além dos electroencefalogramas, são técnicas de imagem, dividindo-se em estáticas e metabólicas [6]. As técnicas estáticas de imagem incluem a angiografia, a tomografia axial computadorizada e a ressonância magnética [6]. Os dois primeiros tipos de exames são baseados em raios-X, permitindo apenas a observação de grandes anormalidades no cérebro, como por exemplo os danos provocados por ataques ou tumores:

- A **angiografia cerebral** permite visualizar os vasos sanguíneos da cabeça, mas requer a introdução na veia fémural, via catéter, de um material contrastante.
- A **tomografia axial computadorizada cerebral** produz múltiplas imagens da cabeça, que são organizadas de forma a permitir uma vista seccionada.

A **ressonância magnética** requer que o cérebro seja atravessado por um forte campo magnético. Um *scanner* rotativo detecta vários padrões de variações electromagnéticas no cérebro. Estas variações são analisadas em computador para produzirem uma imagem tridimensional do cérebro, incluindo informação detalhada sobre a sua estrutura .

As técnicas de imagem metabólicas incluem a tomografia por emissão de positrões e a ressonância magnética funcional [6]. A **tomografia por emissão de positrões** requer o consumo de uma forma de glicose levemente radioactiva que emite positrões quando é metabolizada. O computador analisa os dados resultantes de um *scan* ao cérebro, produzindo imagens com o funcionamento fisiológico do cérebro em acção.

A **ressonância magnética funcional** é parecida com a ressonância magnética, mas usa os aumentos no consumo de oxigénio nas áreas activas para construir imagens da actividade cerebral. Não requer substâncias radioactivas, a máquina cria um campo magnético que induz alterações nos átomos de oxigénio. As diferenças no consumo de oxigénio servem de base às

medições que são analisadas por computador. Esta técnica é menos invasiva que a anterior e pode ter uma resolução temporal maior, mas é bastante dispendiosa e recente.

3.2 Padrões dos Electroencefalogramas

Tal como já foi referido, os registos electroencefalográficos podem mostrar diferentes padrões, dependendo do nível de consciência e do tipo de estímulo. Esta secção descreve os tipos de padrões que em geral são utilizados pelas interfaces computador-cérebro para identificar determinadas actividades mentais.

3.2.1 Ritmos

As ondas cerebrais mostram diferentes actividades rítmicas dependendo do nível de consciência. Estes ritmos podem ser capturados em diversas áreas do córtex cerebral e podem ser usados no reconhecimento de actividades mentais, uma vez que podem ser afectados por diferentes acções e pensamentos (e.g. planear um movimento pode bloquear ou atenuar um dado ritmo) [8].

Os ritmos são divididos em intervalos de frequência e variam consoante a idade. No caso de indivíduos dos 20 aos 60 anos estes são normalmente os seguintes [9] [7]:

Ritmo	Descrição	Quando é que ocorre?
Delta	Varia entre 2 a 4 Hz	<ul style="list-style-type: none">• Sono profundo• Anestesia• Estados de meditação profunda
Teta	Varia entre 4 a 8 Hz	<ul style="list-style-type: none">• Períodos de stress emocional• Sono R.E.M.²
Alfa	<ul style="list-style-type: none">• Ondas regulares com extremos pontiagudos no topo e no fundo.• Varia entre 8 exclusive a 13 Hz.• Maior amplitude na zona posterior do cortex (parietal,temporal e occipital).	<ul style="list-style-type: none">• Condição de descanso.• Temporariamente bloqueado pelo movimento de abrir os olhos e outras actividades mentais.

² A fase do sono R.E.M. (*Rapid Eye Movement*) é caracterizada por ter padrões electroencefalográficos de baixa voltagem, movimentos rápidos dos olhos e actividade muscular reduzida; está associada aos sonhos [9].

Miu	<ul style="list-style-type: none"> • Ondas em forma de arco com amplitude na ordem dos • Varia em entre 7 a 11 Hz • Ocorre nas zonas central e parietal • Alterna com o ritmo Beta. 	<ul style="list-style-type: none"> • Fortemente relacionado a funções motora e tátil. • Bloqueado por movimentos ou estímulos de luz ou tácteis.
Beta	<ul style="list-style-type: none"> • Varia entre 13 a 30 Hz. • Ocorre fundamentalmente nas regiões parietal e frontal. 	<ul style="list-style-type: none"> • Períodos de actividade intensa. • Bloqueado por actividades motoras e estimulação tátil. • Desaparece durante o sono.
Gama	Superior a 30Hz.	Associado à atenção, percepção e cognição

Tabela 1 – Ritmos característicos doselectroencefalogramas.

A figura seguinte mostra as áreas principais do cérebro para contextualizar melhor as referências às localizações espaciais dos ritmos:



Figura 2 – Áreas principais do cérebro. Esta imagem foi adaptada do site “À descoberta da Vida”.

3.2.2 Potenciais Relacionados com Eventos

Os potenciais relacionados com eventos (ou *Event Related Potentials*) são pequenas flutuações de voltagem que reflectem as respostas do cérebro a mudanças ou eventos no ambiente externo ou interno ao organismo [10]. Estes potenciais fornecem informação relevante sobre o tempo que demora o processo cerebral e podem ser usados para identificar os estímulos nos quais o utilizador está concentrado. As interfaces computador-cérebro baseadas neste tipo de fenómenos mostram ao utilizador vários estímulos associados a determinadas acções (e.g. determinadas imagens). O utilizador concentra-se num dos estímulos e o sistema consegue, com base na flutuação resultante, destringir qual a acção a executar.

a) P300

Os P300, um subconjunto dos potenciais relacionados com eventos, são picos positivos que surgem na área do córtex parietal cerca de 300ms após o estímulo [7]. A amplitude do pico resultante é tanto maior, quanto mais rara é a ocorrência do estímulo que o gerou, fornecendo dados sobre a forma como o operador classifica o estímulo e quão raro o considera [11].

b) Potenciais Relacionados com a Constância do Estado Visual

Os potenciais relacionados com a constância do estado visual (ou *Stable State Visual Evoked Potentials*) são oscilações provocadas pela cintilação de estímulos visuais, com uma frequência variável de 2 a 90 Hz, que têm a mesma frequência do estímulo recebido [7]. A amplitude e fase destes potenciais é altamente sensível às características dos estímulos que os originaram nomeadamente: a frequência da intermitência, o contraste, a frequência espacial e as condições ambientais [12].

3.2.3 Oscilações dos Potenciais Corticais Lentos

Os potenciais corticais lentos (ou *Slow Cortical Potentials*) são mudanças de potencial do córtex cerebral que se encontram no intervalo de frequência do 1-2Hz e podem durar entre centenas de milissegundos a vários segundos [6]. As mudanças negativas de potencial indiciam um estado de prontidão, indicando uma redução do limiar de excitação relacionada com a mobilização de recursos para determinadas tarefas cognitivas ou comportamentais [7]. As mudanças positivas indiciam quer um estado de actividade, quer de inibição da actividade neuronal [7].

3.2.4 Dessincronizações e Sincronizações Relacionadas com Eventos

Uma dessincronização relacionada com eventos (ou *Event Related Desynchronization*) é uma atenuação de amplitude de um dado ritmo do electroencefalograma; uma sincronização relacionada com eventos (ou *Event Related Synchronization*) é um aumento de amplitude de um dado ritmo do electroencefalograma. Ambos os padrões são indicativos de determinados estados mentais ou da mudança de estado mental: uma dessincronização no ritmo alfa, por exemplo, é indicativa da activação cortical.

3.3 Interferências

As interferências são perturbações que não fazem parte do sinal resultante da actividade dos neurónios, mas podem afectar o processo de aquisição dos electroencefalogramas. Entre as perturbações mais comuns encontram-se:

- **interferências electromagnéticas** [7], que são geralmente bem delimitadas na frequência (50Hz na Europa – a frequência associada à corrente eléctrica), localizando-se fora da banda referente aos electroencefalogramas.
- **perturbações causadas por movimentos oculares** [7] que se reflectem principalmente nas áreas frontais, podendo ser:
 - **resultantes do piscar dos olhos** — ondas de grande amplitude e baixa frequência, em geral mais elevadas do que os electroencefalogramas.
 - **causadas unicamente por movimentos oculares** — ondas de forma quase quadrada com amplitude semelhante à dos electroencefalogramas.
- **perturbações causadas por movimentos musculares** do pescoço e face [7] — ondas de frequência larga, que surgem principalmente nos eléctrodos que se encontram na zona temporal e parietal.

Menos comuns são, entre outras, as interferências provocadas pelo movimento do sujeito, pela pulsação, pela respiração ou suor, que por exemplo diminui a aderência dos eléctrodos.

4 Tratamento das Interferências

Existem várias técnicas referenciadas que procuram minimizar o efeito provocado pelas perturbações, que prejudica o reconhecimento das acções mentais (referidas na secção 3.3). A tabela abaixo resume as técnicas apresentadas nesta secção.

Categorias	Técnicas de Tratamento de Interferências
Técnicas de controlo do ambiente de medição	Afastamento os fios eléctricos dos eléctrodos Registo do ruído médio
Filtros e bandas	Filtros de ruído Bandas de frequências de controlo

Avaliação das características do sinal	Análise das características de determinados eléctrodos e bandas Análise de correlação Análise de componentes independentes
Outras técnicas	Remoção de tramas com artefactos Utilização de eléctrodos específicos

Tabela 2 - Resumo das técnicas de tratamento de interferências.

As **tramas que contêm interferências são em geral removidas manualmente** [7] [13], uma vez que podem levar a conclusões erradas. Esta solução requer intervenção humana, tratando-se por isso de um processo lento que impede a detecção em tempo real.

Uma forma de evitar as interferências electromagnéticas consiste em **controlar o ambiente de medição**, mantendo, por exemplo, todos os fios eléctricos afastados dos eléctrodos [7]. Uma outra técnica consiste em registar e usar o ruído médio do sinal, obtido através da realização de testes iniciais com o aparelho de medição. Este valor pode ser posteriormente utilizado para filtrar o sinal ou mesmo para determinar a sua banda de frequências.

A utilização de **filtros de ruído** [7] específicos para atenuar ou remover o ruído resultante da corrente eléctrica é uma prática frequente, visto que esta interferência é limitada na frequência, fora da banda específica dos electroencefalogramas.

Uma outra técnica, que procura detectar e remover movimentos oculares, consiste em utilizar **eléctrodos específicos** [14] [15] que são colocados perto da zona ocular dos sujeitos. Sempre que a sua magnitude excede um determinado limiar ($100 \mu V$ [15]), é identificada a existência de um movimento ocular, eliminando-se as tramas contaminadas. Uma alternativa à eliminação das tramas, consiste em **compensar as interferências, utilizando os registos obtidos nos eléctrodos que se encontram perto da zona ocular**, através de determinadas operações de processamento de sinal. Trejo et al. [16], por exemplo, executam uma subtração linear, seguida de um processo de remoção de ruído utilizando *wavelets*.

Um processo utilizado para a detecção de movimentos musculares, que provocam interferências de alta frequência, consiste na definição de **bandas de frequência de controlo** (40 a 64 Hz) [16]. Sempre que a actividade numa dada banda excede um dado limiar, fixado com base na sua variação normal, os dados são ignorados.

Uma outra forma de detectar a ocorrência de artefactos oculares passa pela **análise da densidade espectral de potência** (ver detalhes sobre a densidade espectral de potência na secção 5.1.2) em determinados eléctrodos e bandas do electroencefalograma. Molina, por

exemplo [7], refere que estas perturbações provocam a concentração da densidade espectral de potência no ritmo teta em eléctrodos específicos. De modo similar, quando ocorrem interferências originadas por movimentos musculares num dado eléctrodo, também se verifica a concentração da densidade espectral da potência no ritmo beta.

Por fim, a remoção de perturbações provocadas por movimentos musculares pode ainda processar-se através da **análise da correlação e de componentes independentes** [17]. As componentes independentes serão discutidas na secção 5.4.2; a análise da correlação estuda o nível de relacionamento entre dois sinais com base no índice de correlação que é determinado a partir das suas médias (μ_i) e desvios padrão (σ_i) [18] do seguinte modo:

$$r(x, y) = \frac{\frac{\sum x_i y_i - n \mu_x \mu_y}{n-1}}{\sigma_x \sigma_y}$$

O valor resultante é indicativo do nível de relacionamento entre os dois sinais: quanto maior é em termos absolutos, mais forte é a sua relação. Nesta aplicação específica, quando o índice é fraco estamos perante uma interferência.

5 Extração de Propriedades dos Electroencefalogramas

O objectivo principal desta fase é obter um conjunto distinto de atributos que caracterizam univocamente cada tarefa mental [8]. Estes, são determinados a partir dos registos provenientes dos electroencefalogramas, após sua segmentação em tramas e posterior remoção de artefactos — as perturbações originadas por sinais que não fazem parte da actividade cerebral. Os atributos são então agrupados em vectores de características que são utilizados para o reconhecimento dos padrões das acções mentais a detectar.

Os vários sistemas de comunicação computador-cérebro diferem bastante no tipo de medidas utilizadas para caracterizar os electroencefalogramas. Estas medidas podem englobar a densidade espectral de potência, os coeficientes de autoregressão simples ou multivariáveis, transformadas, a filtragem espacial, entre outras. Uma análise que englobe tempo, frequência e fase pode, contudo, resultar num vector de dimensões demasiado grandes, não se adequando aos requisitos das interfaces computador-cérebro, que incluem a adaptação contínua, um tempo de treino razoável, um tempo de resposta limitado, entre outros [7]. A tabela 3 resume as características apresentadas nesta secção.

Categoria	Características	Aplicação
Propriedades de Frequência e/ou tempo	Energia	Determinação da força do sinal
	Densidade Espectral de Energia	Determinação da força de uma dada banda de frequências em relação às restantes.
	Potência	Detecção de potenciais relacionados com eventos
	Densidade Espectral de Potência	Detecção de padrões e de potenciais relacionados com a constância do estado visual
	Análise de Hjorth	Detecção de foco numa dada tarefa mental
	Análise Wavelet	Detecção potenciais relacionados com eventos e oscilações
Características espaciais	Padrões Espaciais Comuns	Detecção padrões de variância do sinal
	Rácios de Assimetria	Detecção de padrões (caracterizam assimetrias)
Modelos de autoregressão	Coeficientes de Autoregressão	Detecção de padrões
	Coeficientes de Reflexão	Determinação da ordem do modelo
	Coeficientes de Autoregressão Multivariável	Detecção de padrões, tendo vários sinais em simultâneo
Medidas Estatísticas	Complexidade Estocástica	Detecção de padrões em sujeitos diferentes
	Entropia Espectral	Descritor de variabilidade
	Análise de Componentes Independentes	Separação de fontes, detecção de potenciais relacionados com eventos.

Técnicas de otimização	Filtro Laplaciano	Supressão da "desfocagem" introduzida pelos tecidos da cabeça
	Análise de Componentes Principais.	Redução da dimensão dos vectores de características
Outras Medidas	Média de períodos registados	Detecção de potenciais relacionados com eventos
	Detecção de áreas e picos,	Detecção de P300
	Diferenças obtidas em relação a uma dada janela de tempo	Detecção de potenciais corticais lentos.

Tabela 3 - Resumo das características extraídas apresentadas nesta secção.

5.1 Características de Frequência e/ou Tempo

As secções seguintes descrevem propriedades de frequência e/ou tempo que podem ser extraídas a partir dos electroencefalogramas e, por conseguinte, utilizadas em interfaces computador-cérebro.

5.1.1 Energia e Densidade Espectral de Energia

A **energia** de um sinal x_t caracteriza a sua força, calculando a área ocupada pela sua curva [19] [18] – t representa o domínio do tempo e x , a amplitude do sinal:

$$E_x = \int_{-\infty}^{+\infty} x(t)^2 dt$$

A **energia espectral de potência** (ou *power spectral energy*) determina quanta energia existe em cada frequência, permitindo caracterizar a sua relevância no contexto do sinal global [18]. Esta medida é calculada determinando a energia nas várias frequências – w representa o domínio da frequência e X , a transformada de Fourier do sinal x :

$$G_x(\omega) = |X(\omega)|^2$$

Kern e Aunon [14], por exemplo, usam a energia espectral de potência dos vários ritmos nos seus vectores de propriedades.

5.1.2 Potência e Densidade Espectral de Potência

A **potência média** de um sinal é a quantidade de energia por segundo [19], sendo definida do seguinte modo:

$$P_x = \lim_{N \rightarrow \infty} \frac{1}{N} \int_{-N/2}^{N/2} |x(t)|^2 dt$$

x é sinal, N , a sua duração centrada na origem. Esta fórmula é adaptada ao caso discreto e aplicada em pequenos intervalos temporais, determinando-se a potência média nesses intervalos. Bostanov [10], por exemplo, utiliza esta medida na detecção de potenciais relacionados com eventos, procurando detectar áreas e picos de potência em sinais resultantes da média de várias amostras.

A **densidade espectral de potência** (ou *Power Spectral Density*) indica quanta energia existe em média no sinal em função da frequência [18], sendo frequentemente usada na caracterização de electroencefalogramas. Esta medida pode ser determinada utilizando vários métodos, por exemplo através da transformada de Fourier da sua função de autocorrelação – um procedimento com base no teorema de Wiener–Khinchine³ [19] [18]:

$$S_x(\omega) = \int_{-\infty}^{\infty} r_{xx}(\tau) e^{-j\omega\tau} d\tau.$$

r_{xx} é a autocorrelação – o índice de correlação do sinal com ele próprio, τ é o tempo, e ω a frequência.

Outra alternativa referenciada consiste em determinar a densidade espectral de potência directamente a partir dos coeficientes de autoregressão (mais detalhados na secção 5.3) através da seguinte expressão [19] [14] [20]:

$$S_{xx}(\omega) = \frac{2\sigma_\varepsilon^2}{|1 - \sum_{n=1}^M a(n)e^{-j2\pi n\omega}|^2}$$

$a(n)$ é o coeficiente de ordem n , ω a frequência e σ_ε , o desvio padrão do resíduo – o erro resultante da aproximação do sinal através do modelo de autoregressão (ver mais detalhes na secção 5.3)

A análise da densidade espectral de potência é efectuada estudando a sua variação ao longo do tempo. Para isso, é necessário determinar esta medida em pequenas regiões locais do sinal

³ Se o sinal pode ser tratado como um processo aleatório estacionário no sentido lato, a sua densidade espectral de potência é a transformada de Fourier da sua função de autocorrelação [19] [18]. Um processo estacionário no sentido lato deve obedecer às seguintes condições: (i) a média (μ) é constante; (ii) a autocorrelação $r_x(t_1, t_2)$ depende apenas de $t_1 - t_2$; (iii) $r_x(0, 0) - \mu = \sigma^2$ é finita (sendo σ^2 a variância) [19] [18].

recorrendo à **aplicação prévia de janelas** – funções que multiplicam o sinal, sendo 0 fora do intervalo desejado. Neste âmbito, existem algumas referências que estudam o impacto da escolha da janela no desempenho final da classificação das actividades mentais. Kern e Aunon [14], por exemplo, testam janelas retangulares com 2000 e 250ms, tendo obtido resultados mais favoráveis com as últimas. Palaniappan et al. [20] verificam a aplicação de janelas de Tukey e de Parzen com uma duração de 500ms, tendo obtido melhor desempenho com a última. As figuras seguintes mostram os gráficos deste três tipos de janelas:




Figura 3 – As janelas rectangular, de Tukey e Parzen respectivamente.

5.1.3 Análise de Hjorth

A análise de Hjorth [17] [21] é um método de análise clínica de electroencefalogramas que analisa a variação da amplitude do sinal ao longo do tempo. Esta análise representa cada janela do sinal usando simplesmente três aspectos: actividade, mobilidade e complexidade, sem descrever o domínio da frequência. A **actividade** é a variância das flutuações de amplitude num dada janela. A **mobilidade** é determinada através da raiz quadrada da variância da primeira derivada, dividida pela variância do sinal. A **complexidade** é o rácio entre a mobilidade da primeira derivada do sinal e o sinal.

Não existe acordo no que se refere ao que estas três medidas significam em termos de estados mentais, mas assume-se que quanto mais o sujeito se foca numa dada tarefa mental, mais estável é o sinal e portanto, menor é a variância da flutuação da amplitude.

5.1.4 Análise Wavelet

As *wavelets* são funções matemáticas que dividem o sinal em diferentes componentes de frequência, permitindo o estudo de cada componente em diferentes resoluções (ou escalas) [22]. Estas ondas permitem analisar um sinal de forma global e detalhada. Ou seja: se se analisar o sinal numa janela maior, observam-se os aspectos mais grosseiros; se a janela for menor, estudam-se elementos mais pormenorizados. As *wavelets* permitem assim a extracção de dados coerentes quer no domínio da frequência, quer no do tempo: a análise temporal é

efectuada numa versão de menor resolução; a análise na frequência é executada em versões mais dilatadas.

As *wavelets* apresentam algumas vantagens em relação à transformada de Fourier: uma delas é que são particularmente adequadas para analisar situações em que o sinal revela descontinuidades ou picos acentuados, uma vez que são locais⁴. Outra vantagem é o facto das funções que lhes servem de base não serem fixas, existindo infinitas possibilidades de se criarem *wavelets* adequadas a aplicações específicas. A análise *wavelet* usa uma função base – a mãe *wavelet*, neste caso $\Psi(t)$ – a partir da qual são geradas todas as versões de diferente resolução (ou escala) e deslocamento (ou translação):

$$\Psi_{s,\tau}(t) = \frac{1}{\sqrt{s}} \Psi\left(\frac{t - \tau}{s}\right)$$

s é a escala e τ , o deslocamento no tempo. A transformada *wavelet* decompõe uma função $f(t)$ num conjunto de funções Ψ^* :

$$\Psi^*(s, \tau) = \int f(t) \Psi_{s,\tau}^*(t) dt$$

Existem várias famílias de wavelets: *Haar*, *Daubechies*, *Morlet*, *Mexican Hat*, entre outras, cada uma com as suas características específicas e com diferentes aplicações no que se refere às interfaces computador-cérebro.




Figura 4 – As *wavelet MexicanHat* e *Morlet* [34]

As *wavelets* que estão bem localizadas no domínio do tempo, como por exemplo a *Mexican Hat*, são adequadas para detectar potenciais relacionados com eventos [10]; as *wavelets* que estão bem localizadas na frequência, como a *Morlet*, permitem detectar oscilações pronunciadas [10].

⁴ Os senos e cossenos que servem de base à transformada de Fourier não são locais.

5.2 Características Espaciais

As secções seguintes descrevem propriedades que são determinadas com base na distribuição espacial de determinadas medidas pelos vários eléctrodos.

5.2.1 Rácios de Assimetria

Os **rácios de assimetria** permitem quantificar assimetrias entre os dois hemisférios cerebrais, caracterizando o conteúdo espectral. Kern e Aunon [14] determinam estas medidas com base na seguinte fórmula:

$$\frac{R - L}{R + L}$$

R e L são as áreas sob a curva de densidade espectral de potência de um ritmo específico nos eléctrodos situados respectivamente no hemisfério direito e esquerdo. Estes autores utilizam nos seus vectores de propriedades os rácios de assimetria para os ritmos delta, teta, alfa e beta de todas as combinações esquerda-direita de pares eléctrodos.

5.2.2 Padrões Espaciais Comuns

A análise baseada em padrões espaciais comuns [23] [24] (ou *Common Spatial Patterns*) permite a classificação dos padrões em duas categorias de actividades mentais. Esta técnica consiste em descobrir as combinações lineares de eléctrodos que maximizam a variância do sinal para uma classe e a minimizam para a outra. Este processo usa as covariâncias de cada uma das classes, Σ_i , para determinar as matrizes R e D (uma diagonal) tal que:

$$\begin{cases} R\Sigma_1 R^T = D \\ R\Sigma_2 R^T = 1 - D \end{cases} \text{ onde } \Sigma = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})(X_i - \bar{X})^T$$

Cada linha i da matriz D , d_i , é a variância relativa para amostras da classe 1 e variância relativa $1 - d_i$, para amostras da classe 2. Estes valores irão constituir os vectores de aspectos a utilizar na classificação: os padrões espaciais comuns da classe 1 serão as projecções de R correspondendo aos maiores valores de d_i , e os padrões espaciais comuns da classe 2 serão as projecções de R correspondendo aos menores valores de d_i .

5.3 Modelos de autoregressão

Os modelos de autoregressão [14] [15] [19] prevêem os valores de um sinal a partir dos valores passados desse mesmo sinal. As secções seguintes descrevem os modelos simples e multivariável.

5.3.1 Modelos de Autoregressão Simples

Os modelos de autoregressão simples aproximam um dado sinal através de uma única equação [19]:

$$x(t) = \sum_{i=1}^N a_i x(t-i) + \varepsilon(t)$$

Os coeficientes a_i são os **coeficientes de autoregressão**, N , a ordem e ε , o resíduo, em geral assumido como sendo ruído branco de distribuição gaussiana. Os coeficientes de autoregressão são utilizados nos vectores de propriedades usados para classificar os padrões dos electroencefalogramas em determinadas tarefas mentais.

Existem várias formas de determinar os coeficientes de autoregressão, os principais são o **método de Burg** [14] [15], e o **método dos mínimos quadrados** [25].

O método de Burg calcula os coeficientes directamente a partir dos próprios dados. É recursivo e utiliza menos ordens que outros métodos a caminho da solução, sendo portanto mais rápido. Por razões de complexidade não se descreve este método. O método dos mínimos quadrados baseia-se na resolução das equações de Yule-Walker:

$$r_x(m) = \sum_{k=1}^N a_k r_x(m-k) + \sigma_\varepsilon^2 \delta_m, \quad m = 0, \dots, N$$

$r_x(m)$ é a função de autocorrelação de x , σ_ε é o desvio padrão de ε e δ_m é a função delta de Kronecker⁵.

Os **coeficientes de reflexão ou coeficientes negativos de correlação parcial** são um outro tipo de coeficientes, também obtidos a partir de modelos de autoregressão, que podem ser utilizados em vectores de características em interfaces computador-cérebro [13]. Estes coeficientes definem a redução do resíduo, ε , quando se aumenta a ordem do modelo autoregressivo por um, ou seja:

$$E_{m+1} = (1 - \rho_{m-1}^1) E_m \text{ sabendo que } E_m = \sum_t \varepsilon_m^2(t)$$

ρ_m é o coeficiente de reflexão de ordem m .

⁵ $\delta_m = \begin{cases} 1 & \text{se } m = 0 \\ 0 & \text{se } m \neq 0 \end{cases}$

5.3.2 Modelos de Autoregressão Multivariável

Os modelos de autoregressão multivariável têm, em vez de um sinal, um vector de sinais aproximados através de modelos autoregressão simples [26]:

$$X(t) = \sum_{i=1}^N A_i X(t-i) + E(t)$$

X é um vector de sinais, E , um vector de erros residuais e A , uma matriz de coeficientes de autoregressão. Este tipo de modelos adequa-se ao caso da análise e processamento de electroencefalogramas, que, devido aos vários pontos de captura, os eléctrodos, tratam-se efectivamente de um conjunto de sinais. Contêm assim não só o modelo de cada série de tempo, mas também o modelo das relações entre as variáveis incluídas, permitindo determinação de várias conexões fisiologicamente relevantes entre sinais medidos [26].

Para determinar os coeficientes de autoregressão multivariável, Hytti et al [26] utilizam procedimentos baseados na técnica de minimização do erro dos mínimos quadrados referida na secção anterior, mas adaptada a vectores de sinais

5.4 Medidas Estatísticas

As medidas estatísticas utilizam cálculo estatístico para caracterizar os padrões encontrados nos electroencefalogramas. As secções seguintes detalham algumas destas técnicas.

5.4.1 Complexidade Estocástica

As propriedades tradicionais não são aplicáveis quando comparando sinais com diferentes larguras de bandas, como é o caso de diferentes sujeitos e diferentes idades [27]. A frequência base do ritmo alfa, por exemplo, varia com a idade e é característica de cada sujeito. Segundo Miranda e Brouse [27] estas limitações podem ser ultrapassadas através da utilização de atributos que caracterizem a complexidade do sinal, medindo o seu grau de variabilidade, que são além disso facilmente interpretáveis.

Uma destas medidas é **entropia espectral** – a entropia da função de probabilidades da densidade espectral de potência do sinal, que quantifica a complexidade espectral de uma série temporal [17]. Trata-se de uma medida da dispersão dos dados: os dados com uma distribuição de probabilidade ampla e achatada apresentarão um elevado valor de entropia; os dados com uma distribuição estreita e em picos possuirão um baixo valor de entropia.

No caso dos electroencefalogramas, a entropia espectral representa um descritor da sua variabilidade, permitindo medir as alterações que ocorrem no córtex: uma alta entropia ocorre

quando se verifica um grande número de processos (ruído aleatório); uma baixa entropia decorre da existência de um pequeno número de processos (movimentos regulares) [27].

5.4.2 Análise de Componentes Independentes

A análise de componentes independente [23] [11] (ou *Independent Component Analysis*) é uma técnica estatística para separar N fontes estatisticamente independentes que foram misturadas linearmente em N canais, sem qualquer conhecimento sobre as suas distribuições ou dinâmicas [28]. Esta técnica tem-se revelado bastante adequada aos paradigmas cognitivos, para os quais não estão disponíveis modelos detalhados da actividade cerebral. As componentes independentes são obtidas maximizando a independência estatística das componentes estimadas. Para isso é necessária uma fase prévia na qual é determinada a matriz W , uma transformação linear, que minimiza a informação mútua entre canais, tornando-os estatisticamente independentes⁶ [28]:

$$s = Wx$$

x é o vector de dados observados e s será o vector de componentes que se pretende encontrar. Existem vários algoritmos para estimar as componentes independentes, o EEGLab [29], por exemplo, permite utilizar os métodos FastICA, JADE, entre outros.

5.5 Optimização da Extração de Características

Alguns métodos utilizados nas interfaces computador-cérebro não procuram extrair propriedades dos electroencefalogramas, mas permitem otimizar a sua extração, através por exemplo da filtragem de ruído, a diminuição do número de variáveis, entre outras. As secções seguintes descrevem alguns destes métodos com mais detalhe.

5.5.1 Filtro Laplaciano

O Filtro Laplaciano pode ser usado para melhorar e tornar mais destacada a actividade cerebral localizada e suprimir a "desfocagem" introduzida pelos tecidos da cabeça [30]. Este filtro é aplicado através da combinação linear dos potenciais de um conjunto de eléctrodos espacialmente próximos [19]. Este filtro requer poucos recursos computacionais, pois é facilmente aplicado, suprime o ruído comum, mas é sensível a ruído localizado não resultante

⁶ Duas variáveis aleatórias são estatisticamente independentes se o conhecimento do valor de uma não afecta a densidade de probabilidade da outra; se todas as variáveis aleatórias de um processo aleatório forem estatisticamente independentes, então: $P(x_1, \dots, x_n) = \prod_n P(x_n)$

da actividade cerebral, e, devido às diferenças de condutividade dos tecidos, os seus resultados variam de pessoa para pessoa [30].

5.5.2 Análise de Componentes Principais

A análise de componentes principais **Error! Reference source not found.** (ou *Principal Component Analysis*) é uma transformada linear que permite simplificar um conjunto de dados, reduzindo-o a menores dimensões. Esta análise permite quantificar e seleccionar a quantidade de informação útil, em oposição ao ruído e variações insignificantes nos dados. Os dados são assim transformados num novo sistema de coordenadas de forma a que a primeira coordenada assuma a maior variância, a segunda, a segunda maior variância e assim sucessivamente. As coordenadas de menor variância são ignoradas, mantendo-se assim as propriedades que mais contribuem para a sua variância.

Não existe um conjunto fixo de vectores base para determinar as componentes principais, pois este depende do conjunto dos dados iniciais. Utilizam-se como base os valores próprios da matriz de covariâncias. Pretende-se assim transformar x em u tal que:

$$\begin{bmatrix} u_1 \\ \vdots \\ u_n \end{bmatrix} = \begin{bmatrix} v_1 \\ \vdots \\ v_n \end{bmatrix} \begin{bmatrix} x_1 \\ \vdots \\ x_n \end{bmatrix}$$

u_1 é a primeira componente principal, u_2 , a segunda e assim sucessivamente. Se ordenarmos por ordem decrescente os valores próprios da matriz de covariâncias, v_i é o i -ésimo valor próprio da matriz de covariâncias.

5.6 Outras Características dos Electroencefalogramas

As secções seguintes descrevem procedimentos que, embora não façam explicitamente parte das classificações anteriores, são relevantes no âmbito deste relatório, como é o caso, por exemplo, dos potenciais relacionados com eventos e das oscilações dos potenciais corticais lentos.

5.6.1 Potenciais Relacionados com Eventos

A utilização de potenciais relacionados com eventos em interfaces computador-cérebro tem por base a possibilidade de discriminar potenciais distintos provocados por eventos externos distintos [7], por exemplo piscar objectos no ecrã, sons curtos, etc. Estas alterações eléctricas podem ser extraídas dos registos dos electroencefalogramas determinando a média de períodos registados (épocas) de ocorrências repetidas de eventos sensoriais, cognitivos ou motores [8]. As variações espontâneas dos electroencefalogramas são desta forma removidas,

deixando nos registos as flutuações provocadas pelos potenciais relacionados com eventos, e por conseguinte os padrões de actividade neuronal originados pelo estímulo. No caso dos sistemas síncronos, as médias são utilizadas apenas para o treino dos classificadores.

a) P300

A detecção de P300 não requer treino inicial, embora estes fenómenos possam ser utilizados em sistemas condicionados. Nestes casos, estes estímulos são associados a acções a executar através da interface computador-cérebro e os utilizadores treinados para revelar a escolha pretendida **Error! Reference source not found..** O desempenho destas interfaces pode contudo ser diminuído com a rotina e habituação, uma vez que estas atenuam os P300.

A detecção de componentes P300 processa-se também através do reconhecimento de padrões em registos resultantes da média de várias tentativas [11]. Este reconhecimento realiza-se recorrendo a métodos como a análise discriminante, detecção de áreas e picos, *wavelets*, análise de componentes independentes, entre outras.

Xu et al [11], por exemplo, utilizam uma análise de componentes principais seguida de uma análise de componentes independentes, eliminando algumas das componentes obtidas através da sua análise temporal e espacial. Estas componentes são então projectadas espacialmente na cabeça para obter a sua distribuição.

b) Potenciais Relacionados com a Constância do Estado Visual

Estes potenciais são detectados examinando as características espectrais dos sinais registados pelos eléctrodos relativos à área visual. A utilização destes fenómenos em interfaces computador-cérebro baseia-se na discriminação das frequências dos vários potenciais relacionados com a constância do estado visual, que são previamente associados a diferentes acções. Piccini et al. [12], por exemplo, identificam estes fenómenos através de determinação da densidade espectral de potência das primeiras três harmónicas da frequência de cada estímulo.

5.6.2 Oscilações dos Potenciais Corticais Lentos

É possível treinar os utilizadores para associar acções distintas às oscilações negativas e positivas, permitindo também o seu controlo através de interfaces computador-cérebro. Estas oscilações podem ser detectadas através da análise da constância sinal e das diferenças obtidas em relação a uma dada janela de tempo.

6 Técnicas de Classificação

Os aspectos extraídos, referidos na secção anterior, são utilizados em classificadores — algoritmos que classificam os padrões em determinadas categorias de actividades mentais, tipicamente 2 a 5 classes [8]. Estes algoritmos determinam a probabilidade de um dado vector de características pertencer a uma dada classe. A classe com maior probabilidade será a escolhida. Existem alguns sistemas de comunicação computador-cérebro que rejeitam alguns os vectores quando esta probabilidade não excede um dado limiar [8].

Um classificador pode ser desde um modelo linear simples, a uma complexa rede neuronal não linear [8]. A tabela seguinte resume os métodos descritos nesta secção.

Categoria	Técnicas	Descrição
Métodos de agrupamento (sem supervisão)	K-vizinhos mais próximos	Agrupam os vectores de acordo com as suas características.
Redes Neurais	Perceptrões multi-camada	Classificação de vectores de características (com supervisão)
	Redes neurais com função de transferência de base radial	Treino mais rápido, requerem decisão prévia do número de centros e respectivas distâncias.
	Rede neuronal Fuzzy ARTMAP	Aprendizagem incremental
Partição do espaço de vectores (com supervisão)	Análise Discriminante (Linear e Quadrática)	Utilização de funções discriminantes
	Máquinas de Suporte Vectorial	Maximização da separação entre partições
Classificadores Não Lineares	Modelos de Markov Não Observáveis	

Tabela 4 - Resumo das técnicas de classificação apresentadas.

6.1 K-Vizinhos mais Próximos

A técnica dos k-vizinhos mais próximos tem sido usada com sucesso em interfaces computador-cérebro com vectores de baixas dimensões [7]. O objectivo principal deste método é atribuir a um dado exemplo, não classificado, a classe dominante entre os k vizinhos mais próximos dentro do conjunto de treino [31]. Este método apresenta alguns problemas

relacionados com o tamanho dos vectores utilizados, quer sob o ponto de vista computacional, quer devido à relevâncias dos atributos para a classificação.

6.2 Redes Neurais

Existem vários sistemas de comunicação computador-cérebro que usam redes neurais para classificar actividades mentais [8]. Uma rede neuronal artificial [31] é um grupo de neurónios artificiais interligados que usam um modelo computacional que aproxima as características biológicas do sistema nervoso. Estas redes podem ser usadas para modelar relações complexas entre parâmetros e resultados ou para reconhecer e classificar determinados padrões nos dados.

Os elementos que constituem as redes neurais, os neurónios, contêm entradas, através das quais adquirem informação, que são influenciadas por pesos, associados às conexões com os outros neurónios, e uma saída. Os valores das entradas são combinados através da aplicação de uma função de combinação; o valor da saída resulta da aplicação de uma função de transferência, que permite calcular o estado do neurónio. Os neurónios encontram-se ligados de forma a que as saídas de uns estão ligadas às entradas de outros, podendo existir diversos tipos de arquitectura.




Figura 5 – Rede neuronal multi-camada e unidireccional.

As redes neurais são treinadas através de um processo de aprendizagem, que pode ser por reforço, supervisionada ou não supervisionada. Estas redes apresentam uma boa generalização, mas são difíceis de treinar [20].

No contexto das interfaces computador-cérebro, existem vários tipos de redes neurais que têm vindo a ser utilizadas para reconhecer padrões em electroencefalogramas. Anderson et al. [15], por exemplo, utilizam **perceptrões multi-camada** – redes neurais treinadas com o algoritmo de retro-propagação do gradiente. Estas redes possuem um a dois níveis escondidos, podendo aproximar em teoria qualquer mapeamento de entradas e saídas.

Sykacek et al [13] utilizam as **redes neurais com função de transferência de base radial**, que são desenvolvidas de acordo com um critério de distância em relação a um centro. Estas redes envolvem três camadas, sendo as suas saídas uma combinação linear das funções de

base radial determinadas pelos neurónios da camada escondida. Estas redes podem ser treinadas de forma mais rápida que as redes multi-camada, mas requerem uma decisão prévia do número de centros e respectivas distâncias. Os centros devem reflectir o agrupamento natural dos dados.

Um outro tipo de rede neuronal bastante mais recente é a **rede neuronal Fuzzy ARTMAP**, usada por Palaniappan et al [20]. Estas redes simplificam a fase de treino, caracterizando-se por permitir aprendizagem incremental — o treino da rede com novas amostras sem necessitar de treinar novamente as amostras anteriormente utilizadas.

As redes Fuzzy ARTMAP são compostas por dois módulos, ARTa e ARTb, que estão ligados por uma série de conexões às quais estão associados pesos. Durante o treino, o ARTa recebe um vector de aspectos de entrada, que representam o padrão, e o ARTb recebe um vector de aspectos de saída, que representa a classe alvo desejada para esse padrão. A rede usa então uma espécie de teste de hipóteses para classificar os dados. Por exemplo, quando recebe o primeiro vector, assume que este pertence a um dada classe; quando recebe o segundo, confirma ou rejeita essa hipótese. Isto processa-se tendo em consideração determinados critérios de correcção, procurando minimizar o erro de previsão e maximizando a generalização prevista.

6.3 Análise Discriminante

A análise discriminante é usada por várias interfaces computador-cérebro na fase da classificação. Esta forma de análise representa um classificador através de uma família de funções discriminantes, g_i , uma por classe w_i . Considera-se que um dado vector de características pertence à classe que assume o maior valor após a aplicação da função discriminante, ou seja:

$$x \in w_i \Leftrightarrow g_i(x), \forall j \neq i$$

Estas funções dividem o espaço da solução em partições correspondentes às classes — hiperplanos.

Bostanov [10] utiliza a **análise discriminante linear** que é a técnica de análise discriminante mais usada, tendo como principal vantagem o facto de computacionalmente rápida. Esta análise é aplicável se as classes podem ser separadas através da combinação linear de atributos. A função discriminante desta análise é a seguinte:

$$g_i(x) = -\frac{1}{2}(x - \mu_i)^T \Sigma^{-1}(x - \mu_i) - \log(P(w_i))$$

Σ é a matriz de covariância e μ , a média do sinal. Neste caso, assume-se que as classes têm funções de densidade probabilística de distribuição normal e covariâncias iguais.

Para classificar as tarefas mentais, Kern e Aunon [14] usam a **análise discriminante quadrática**. A função discriminante quadrática é seguinte:

$$g_i(x) = -\frac{1}{2}(x - \mu_i)^T \Sigma_i^{-1} (x - \mu_i) - \frac{1}{2} \log(|\Sigma_i|) + \log(P(w_i))$$

Σ é a matriz de covariância e μ , a média do sinal. Este tipo de análise não requer a igualdade das matrizes de covariância, mas também assume a distribuição normal dos dados.

6.4 Máquinas de Suporte Vectorial

As máquinas de suporte vectorial são classificadores lineares que têm vindo a ser usados com sucesso em alguns sistemas síncronos de comunicação computador-cérebro [8] [32]. Trata-se de um conjunto de métodos de aprendizagem com supervisão que, com base num conjunto de exemplos de treino já classificados, procuram estimar uma função de decisão que classifique correctamente vectores ainda não obtidos.

Estes classificadores são semelhantes à análise discriminante linear, na medida em que particionam também o espaço da solução em hiperplanos através de funções discriminantes. Esta técnica procura, contudo, minimizar o erro empírico (ou erro médio da aplicação desta função ao conjunto de treino) e em simultâneo maximizar a separação entre as várias partições – a margem geométrica, aumentando a capacidade de generalização. Isto é conseguido maximizando a distância aos pontos de treino mais próximos – os vectores de suporte.

Este algoritmo é simples, imune à dimensionalidade, mas apresenta baixa velocidade de execução [32].

6.5 Modelos de Markov Não Observáveis

Um processo de markov discreto de ordem p é um sistema em que o estado actual depende apenas de p estados passados [33]. Isto considerando que :

- em cada instante de tempo o sistema se encontra no estado i de entre N estados possíveis S_1, S_2, \dots, S_n
- o sistema evolui a intervalos de tempo regulares para outro estado ou eventualmente permanece no mesmo, em função de uma probabilidade de transição entre estados

Os estados passados de um processo de markov discreto de ordem p são irrelevantes para a prever os estados futuros, desde que seja conhecidos pelo menos p estados, ou seja:

$$P(X_n = S_n | X_{n-1} = S_{n-1}, \dots, X_1 = S_1) = P(X_n = S_n | X_{n-1} = S_{n-1}, \dots, X_{n-p} = S_{n-p})$$

Um classificador baseado neste tipo de processos pretende assim determinar a probabilidade de ocorrerem um conjunto de observações O_i com base no modelo, ou seja:

$$P(O_1, \dots, O_m | Modelo)$$

Quando a cada observação corresponde a um estado, chamam-se a estes processos modelos de markov observáveis [33]. No caso dos modelos de markov não observáveis a mesma sequência de observações pode ser gerada através de sequências diferentes de estados, pois cada estado tem associada uma função de distribuição de probabilidade de observações. Neste caso a sequência de estados que gera uma sequência de observações não é conhecida [33].

Um modelo de markov não observável é assim um tipo de autómato probabilístico, em que cada estado modela a probabilidade de se observar um dado vector de propriedades. Segundo Lotte et al [32], este tipo de modelos é bastante adequado para classificar séries temporais, nas quais se incluem os electroencefalogramas. Estes autores referem que, embora não esteja muito divulgada na comunidade das interfaces computador-cérebro, existem estudos que revelam tratar-se de uma técnica promissora.

Neste âmbito, por exemplo, Sykacek et al [13] baseiam-se em processo de Markov de primeira ordem num classificador adaptativo, que se adapta às variações do sinal originadas pelas várias repetições de uma dada actividade mental.

7 Discussão das Técnicas Apresentadas

Os resultados das várias referências consultadas apontam para algumas dificuldades em comparar os vários procedimentos de análise e processamento utilizados. Por exemplo, existem grandes diferenças entre as medições obtidas em sujeitos distintos, devido aos diferentes graus de experiência com as interfaces computador-cérebro e às combinações de actividades e estratégias mentais por estes seleccionadas [8]. Devido a isto, estes algoritmos requerem uma calibração e treino específico para cada sujeito [8] [14] [15]. Verifica-se também alguma variabilidade de resultados obtidos com o mesmo sujeito em dias diferentes, resultado do seu estado mental actual. Isto sugere que estes classificadores tenham que ser retreinados frequentemente, e que os classificadores adaptativos são uma eventual solução para este aspecto [13].

Uma outra razão para a dificuldade em comparar a eficácia das técnicas de processamento e análise usadas pelos vários sistemas de comunicação computador-cérebro, é o facto de os

resultados serem reportados de forma diferente ou incompleta nos vários artigos: em geral refere-se apenas a taxa de correcção da classificação. A velocidade é também um aspecto importante a ter em consideração, sendo crucial nos mecanismos síncronos, pois pode ter impacto no tempo de resposta da interface [8].

Adicionalmente, não existem estudos publicados significativos que comparem estas técnicas, que idealmente deveriam ser testadas dentro do mesmo contexto, nomeadamente sobre uma mesma plataforma e conjunto de dados. Existem algumas referências que actuam sobre o mesmo conjunto de dados [14] [15] utilizando diferentes características e classificadores. As diferenças de desempenho obtidas entre elas foram contudo pouco significativas, verificando-se algumas diferenças de contexto, nomeadamente no que se refere à aplicação de janelas temporais.

Lotte et al [32] fazem um levantamento de várias técnicas de classificação e consideram que nos sistemas síncronos de comunicação computador-cérebro as máquinas de suporte vectorial são bastante eficientes, independentemente do número de classes, bem como combinações de classificadores simples e classificadores adaptativos; não recomendam nenhum classificador em particular para os sistemas assíncronos.

8 Conclusões

Este estudo apresentou algumas das técnicas de processamento e classificação mais importantes utilizadas nas interfaces computador-cérebro: uma forma inovadora para comunicação com dispositivos, única e exclusivamente através da mente. Foi referido que, para além de poderem vir a desencadear uma eventual revolução no campo das interfaces, estes mecanismos podem ser aplicados em diversas áreas, como é o caso do controlo imersivo de jogos, da estimulação eléctrica funcional ou do desenvolvimento de interfaces para pessoas com deficiência.

Neste âmbito, este estudo incidiu particularmente nas técnicas de análise e processamento de electroencefalogramas: os registos de actividade cerebral mais usados nas interfaces computador-cérebro. Foi ainda referido que a aplicação destas técnicas é complexa, visto que os padrões cerebrais variam com o utilizador, a idade e podem ser contaminados por vários tipos de interferências. Foram assim apresentadas, além de várias características dos electroencefalogramas, várias propriedades usadas pelos actuais sistemas de comunicação computador-cérebro para caracterizar os padrões das actividades mentais que pretendem reconhecer.

Adicionalmente, falou-se ainda do tratamento das interferências que não são resultantes da actividade mental, mas que contaminam os electroencefalogramas, e das técnicas de reconhecimento de padrões mais utilizadas nas interfaces computador-cérebro, que procuram classificar os vectores constituídos pelas características extraídas em determinadas acções mentais.

No que se refere aos métodos de classificação referidos neste estudo, existem ainda outras técnicas de aprendizagem que eventualmente podem ser exploradas e bem sucedidas, nomeadamente a questão das técnicas de agrupamento e mesmo de aprendizagem por reforço, que poderá ser combinada com a realimentação dada pelo utilizador que usa a interface computador-cérebro.

Tal como outras áreas, a multidisciplinariedade que serve de base a estes sistemas é simultaneamente uma oportunidade e um entrave. A concepção e desenvolvimento de interfaces computador-cérebro requer, por exemplo, conhecimentos médicos, de processamento de sinal, matemáticos, informáticos, entre outros. Para se encontrarem os melhores métodos de extracção de características é preciso conhecer-se a fundo as características fisiológicas dos electroencefalogramas.

Adicionalmente, verifica-se ainda a questão da disponibilização de um conjunto alargado de dados, proveniente de vários utilizadores, obtidos em diferentes dias, e de uma plataforma técnica única que sirva de contexto comum à comparação dos resultados obtidos.

9 Referências

1. **Orosz, Edward S. e Anderson, Charles W.** Classification of EEG Signals Using Sparse Polynomial Builder. *Technical Report 94-111, Computer Science, Colorado State University*. 1994.
2. **Millán, José de R.** Adaptive Brain Interfaces. *ACM*. 2003.
3. **Lalor, E., et al.** Brain Computer Interface on the Steady-State VEP for Immersive Gaming Control. *Biomedizinische Technik*. 2004.
4. **Funada, Mariko F., et al.** Usability of EEG Signals for FES Control – through Event Related Potentials Caused by Obscure Pictures. *7th Vienna International Workshop on Functional Electrical Stimulation*. 2001.
5. **Cho, B. H., et al.** Attention Enhancement System using Virtual Reality and EEG Biofeedback. *IEEE Virtual Reality*. 2002.
6. **Steinberg, Robert J.** Cognitive Psychology. *Thomson Wadsworth*. 2003.

7. **Molina, Gary.** *Direct Brain-Computer Communication Through Scalp Recorded EEG Signals.* Lausanne : École Polytechnique Fédérale de Lausanne, 2004. PhD Thesis.
8. **Lehtonen, Janne.** EEG-based Brain Computer Interfaces. *Master Thesis, Department of Electrical and Communications Engineering, HELSINKI UNIVERSITY OF TECHNOLOGY.* 2002.
9. **Fisch, Bruce J.** Fish and Spehlmann's EEG Primer. *Elsevier.* 1999.
10. **Bostanov, Vladimir.** BCI Competition 2003 – Data Sets Ib and Iib: Feature Extracion Form Event-Related Potentials With Continuos Wavelet Transform and the t-Value Scalogram. *IEEE.* 2004.
11. **Xu, Neng, et al.** BCI Competition 2003-Data Set Iib: Enhancing P300 Wave Detection Using ICA-Based Subspace Projections for BCI Applications. *IEEE Transactions on Biomedical Engineering.* 2003.
12. **Piccini, Luca, et al.** A Wearable Home BCI System: preliminary results with SSVEP protocol. *Enginnering In Medicine and Biology.* 2005.
13. **Sykacek, Peter, Roberts, Stephen J. e Stokes, Maria.** Adaptive BCI Based on Variational Bayesian Kalman Filtering: An Empirical Evaluation. *IEEE Transactions on Biomedical Engineering.* 2004.
14. **Kern, Zachary e Aunon, Jorge.** A New Mode of Communication Between Man and His Surroundings. *IEEE.* 1990.
15. **Anderson, C. W., Stolz, E. A. e Shamsunder, S.** Multivariate autoregressive models for classification of spontaneous electroencephalogram during mental tasks. *IEEE Transactions on Biomedical Engineering.* 1998.
16. **Trejo, Leonard J., Rosupal, Roman e Mathews, Bryan.** Brain-Computer Interfaces 1-D and 2-D Cursor Control: Designs Using Volitional Control of the electroencefalograma Spectrum or Steady-State Visual Evoked Potenciales. *IEEE Transactions on Neural System.*
17. **Novak, D., et al.** Electroencephalogram processing using Hidden Markov Models. *Report Transdisciplinary Biomedical Engineering Research.* 2003.
18. **Moon, Todd K. e Stirling, Wynn C.** Mathematical Methods and Algorithms for Signal Processing. *Prentice Hall.* 2000.
19. **Bruce, Eugene N.** Biomedical Signal Processing and Signal Modeling. *John Wiley & Sons.* 2001.

20. **Palaniappan, Ramaswamy, et al.** A New Brain–Computer Interface Design Using Fuzzy ARTMAP. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*. 2002.
21. **Rezek, lead, Roberts, Stephen J e Sykacek, P.** Stochastic Complexity Measures for Physiological Signal Analysis. *IEEE Transactions on Biomedical Engineering*. 1998.
22. **Graps, Amara.** An Introduction to Wavelets. *IEEE Computational Science and Engineering*. 1995.
23. **Schalk, Gerwin, McFarland, Dennis e Hinterberge, Thilo.** BCI2000: A General-Purpose Brain-Computer Interface (BCI) System. *IEEE Transactions on Biomedical Engineering*. 2004.
24. **Blanchard, Gilles e Blankertz, Benjamin.** BCI Competition 2003: Data Set Ila – Spatial Patterns of Self-Controlled Brain Rhythm Modulations. *IEEE Transactions on Biomedical Engineering*,. 2003.
25. **Adlakha, Amit.** Single Trial EEG Classification. *Technical Report, Swiss Federal Institute of Technology*. 2002.
26. **Hytti, Heli, Takalo, Reijo e Ihlainem, Heimo.** Tutorial on Multivariate Autoregressive Modeling. *Journal of Clinical Monitoring and Computing, Online first*. 2006.
27. **Miranda, Eduardo e Brouse, Andrew.** Toward Direct Brain-Computer Musical Interfaces. *Proceedings of the 2005 International COnference on New Interfaces for Musical Expression, NIME05*. Vancouver, Canada : s.n., 2005.
28. **Makeig, Scott.** Frequently Asked Questions about ICA applied to EEG and MEG Data. *Institute for Neural Computation, University of California San Diego*. [Online] <http://www.sccn.ucsd.edu/~scott/tutorial/icafaq.html>.
29. **Swartz Center for Computational NeuroScience.** EEGLAB. *EEGLAB*. [Online] 2007. <http://www.sccn.ucsd.edu/eeglab/>.
30. **Mlynář, J., Šťastný, J. e Sovka, P.** The influence of the electroencefalograma recording Machine Time Multiplex on the Laplacian Filter: The simulation with the real shaped mode. *EMBECE'05, European Medical and Biological Engineering Conference*. 2005.
31. **Mitchell, Tom M.** Machine Learning. *McGraw-Hill*. 1997.
32. **Lotte, F, et al.** A Review of Classification Algorithms for electroencefalograma-based Brain-Computer Interfaces. *TOPICAL REVIEW, INRIA*.
33. **Ribeiro, Carlos Eduardo de Meneses.** Modelos de Markov Não Observáveis. *Processamento Digital de Fala*. [Online] <http://www.deetc.isel.ipl.pt/comunicacoesep/disciplinas/pdf/>.

10 Glossário

AR - Autoregressão

BCI - *Brain computer interface* (Tradução: interface computador-cérebro)

CSP - *Common spatial patterns* (Tradução: padrões espaciais comuns)

EEG - Electroencefalograma

ERD- *Event related desynchronization* (Tradução: dessincronizações relacionadas com eventos)

ERS- *Event related synchronization* (Tradução: sincronizações relacionadas com eventos)

ERP - *Event Related Potentials* (Tradução: potenciais relacionados com eventos)

FAM - *Fuzzy ARTMAP Neural Network* (Tradução: rede neuronal Fuzzy ARTMAP)

ICA – *Independent Component Analysis* (Tradução: análise de componentes independentes)

LDA - *Linear discriminant analysis* (Tradução: análise discriminante linear)

MAR - *Multivariate autoregression* (Tradução: autoregressão multivariável)

PCA - *Principal component analysis* (Tradução: análise de componentes principais)

PSD - *Power spectral density* (Tradução: densidade espectral de potência)

PSE - *Power spectral energy* (Tradução: densidade espectral de energia)

RBF - *Radial basis function* (Tradução: função de transferência de base radial)

SCP - *Slow cortical potentials* (Tradução: potenciais corticais lentos)

SSVEP - *Stable state visual evoked potentials* (Tradução: Potenciais relacionados com a constância do estado visual)

SVM - *Support Vector Machines* (Tradução: Máquinas de Suporte Vectorial)